

УДК 528.8:528.9+551.465.433(597)  
DOI 10.33764/2411-1759-2024-29-6-70-82

## Картографирование приливно-отливных отмелей вдоль побережья Вьетнама с использованием методов глубокого обучения на основе изображения Sentinel-1

Д. Т. Куен <sup>1✉</sup>, В. А. Малинников <sup>1</sup>, Т. Э. Серেকে <sup>1</sup>, С. Х. Нго <sup>2</sup>

<sup>1</sup> Московский государственный университет геодезии и картографии,  
г. Москва, Российская Федерация

<sup>2</sup> Государственный университет по землеустройству, г. Москва, Российская Федерация  
e-mail: quyendinh TUYEN97@mail.ru

**Анотация.** Статья представляет результаты исследования, использующего методы дистанционного зондирования и глубокого обучения сети U-Net в сочетании с техниками трансферного обучения и дообучения сети для изучения и управления приливно-отливными отмелями – важной частью водно-болотных угодий у прибрежных зон Вьетнама. Использование изображений со спутника Sentinel-1 позволяет непрерывно наблюдать в любых погодных условиях, благодаря способности проникать сквозь облака и не зависеть от погоды. Авторы разработали модель глубокого обучения U-Net, применив при этом трансферное обучение и дообучение сети для оптимизации процесса обучения данных. В результате была создана модель, способная автоматически классифицировать приливно-отливные отмели с высокой точностью, достигающей 94,42 %. Для обучения модели были использованы данные, собранные из различных географических мест как в северных, так и в южных регионах Вьетнама. Затем эта модель была применена для определения площади приливно-отливных отмелей вдоль всего побережья 28 провинций Вьетнама. Кроме того, модель была расширена для определения морфологии отмелей, что предоставляет полезную информацию для управления прибрежными водно-болотными угодьями и защиты береговой линии.

**Ключевые слова:** приливно-отливные отмели, дистанционное зондирование, глубокое обучение, сеть U-Net, Sentinel-1, Вьетнам, водно-болотные угодья, морфология приливно-отливных отмелей, геоинформационное картографирование, карты водно-болотных угодий

### Для цитирования:

Куен Д. Т., Малинников В. А., Серেকে Т. Э., Нго С. Х. Картографирование приливно-отливных отмелей вдоль побережья Вьетнама с использованием методов глубокого обучения на основе изображения Sentinel-1 // Вестник СГУГиТ. – 2024. – Т. 29, № 6. – С. 70–82. – DOI 10.33764/2411-1759-2024-29-6-70-82

### Введение

Экосистема прибрежной зоны моря играет немаловажную роль в процветании человечества благодаря разнообразным биологическим ресурсам и различным услугам, которые она предоставляет [1, 2]. Несмотря на то, что научные знания о многих прибрежных экосистемах, таких как мангровые леса, коралловые рифы и морские луга, уже известны, эти экосистемы быстро исчезают

и сталкиваются с многочисленными угрозами, вызванными человеческой деятельностью, включая и экосистему приливно-отливных отмелей. Приливно-отливные отмели широко распространены вдоль побережья всего мира и играют важную роль в прибрежных водных местностях [3]. Первое условие для формирования многих прибрежных экосистем с мелкой осадочной фракцией — это наличие рек, приносящих и выносящих мелкие осадки в устья рек

и прибрежные районы, создавая условия для образования приливно-отливных отмелей. Приливно-отливные отмели в основном распространены вдоль побережья, в защищенных районах, таких как заливы, коралловые рифы и устья рек.

Исследование и управление прибрежными отмелями регулируется Министерством природных ресурсов и экологии Вьетнама (Подробные правила к некоторым положениям Декрета Правительства № 43/2014/ND-CP и Декрета Правительства № 44/2014/ND-CP от 15.05.2014. – URL: <https://thuvienphapluat.vn/van-ban/Bat-dong-san/Thong-tu-02-2015-TT-BT-NMT-huong-dan-Nghi-dinh-43-2014-ND-CP-Nghi-dinh-44-2014-ND-CP-266954.aspx>. – Текст: электронный). Этот документ определяет порядок управления и использования прибрежных отмелей рек, морских отмелей и земель прибрежных вод для сельского хозяйства, лесного хозяйства, аквакультуры и солеварения. Для эффективного управления прибрежными отмелями требуется составление управленческой документации, включая инвентаризацию, перепись и замеры для определения площади отмелей и составления ежегодных отчетов. Согласно Плану № 02/КН-ВТНМТ от 16.09.2014, предусмотрено проведение инвентаризации прибрежных отмелей в 215 поселениях в 13 прибрежных провинциях Вьетнама.

Методы полевых исследований учета приливно-отливных отмелей сложны и затратны [4]. Из-за сложного рельефа и частых изменений уровня приливов, традиционные методы геодезии и GPS затруднительны, а в некоторых местах, например, на отмелях с толщиной мерзлой грязи от 1 до 1,5 м, невозможны.

Точное картографирование приливно-отливных отмелей важно для мониторинга природных ресурсов [5, 6]. Оптические изображения, такие как LANDSAT, SPOT, ALOS, QuickBird, эффективны благодаря широкому охвату, но чувствительны к облачности и метеоусловиям [7]. Эти снимки позволяют определить границы морской линии, но частые изменения уровня приливов усложняют выбор подходящих изображений [8].

Для решения этой проблемы предлагается использовать радиолокационные изображения. Радиолокационные изображения не подвержены воздействию облаков и обеспечивают стабильные данные благодаря возможности наблюдения в любых погодных условиях, как днем, так и ночью, позволяя проводить более полное и точное измерение площади приливно-отливных отмелей.

В последние годы методы машинного обучения доказали свою эффективность в распознавании образов на изображениях [9, 10]. Глубокие сверточные нейронные сети широко используются для извлечения информации с высокой точностью в управлении водными участками, такими как определение мангровых лесов, автоматическая классификация водно-болотных угодий вдоль береговой линии и так далее [11]. Одним из факторов, обеспечивающих точность, является успешное функционирование сети U-Net, превосходящее другие сети [11–14]. Это приводит к использованию данной нейронной сети в сочетании с масками для обучения радарных изображений с целью прогнозирования и количественной оценки изображений приливно-отливных отмелей с максимальной полнотой и точностью.

Цель данного исследования – разработка и применение модели глубокого обучения U-Net для автоматического распознавания приливно-отливных отмелей с высокой точностью на данных спутниковой съемки Sentinel-1 SAR в различных географических зонах Вьетнама. Исследование фокусируется на северной области (Куангнинь) и южной прибрежной зоне (Бакльеу и Соктранг).

После обучения и проверки модели авторы планируют применять ее для автоматического распознавания приливно-отливных отмелей вдоль всей территории Вьетнама. На основе результатов они намерены расширить исследование для определения морфологии отмелей в других прибрежных зонах, что предоставит важную информацию для понимания динамики экосистем и поможет в разработке мер по защите и управлению морскими ресурсами страны.

## Методика исследования

### Метод определения приливо-отливных отмелей на основе глубокого обучения

Традиционные методы и оптические датчики, основанные на солнечном излучении, давно применяются для обнаружения приливо-отливных отмелей, используя индексы, такие как NDWI и MNDWI, зависящие от различий в поглощении излучения в NIR и зеленом диапазонах. Вода поглощает больше излучения в NIR, а суша – в зеленом, что делает эти индексы выше на воде и ниже на суше [15, 16].

Однако оптические изображения зависят от погодных условий и облачности, что затрудняет сбор данных. Сенсоры, такие как Landsat и Sentinel-2, ограничены в регионах с частой облачностью и осадками.

Изображения, полученные с помощью Sentinel-1 SAR, позволяют собирать данные вне зависимости от погодных условий, включая облачность. SAR предоставляет информацию о структуре поверхности за счёт отражения радиоволн, что позволяет эффективно отслеживать изменения приливных отмелей в любых метеорологических условиях.

Сочетание глубокого обучения и спутниковых изображений Sentinel-1 было доказано эффективным в определении приливо-отливных отмелей [17]. В данном исследовании авторы использовали сверточную нейронную сеть U-Net с маркировкой приливо-отливных отмелей для обучения и повышения точности с помощью метода передачи обучения и техники тонкой настройки сети.

Метод исследования (рис. 1), использованный в исследовании для определения приливо-отливных отмелей, описывается следующим образом:




Рис. 1. Схема исследования

Шаг 1: Выбор обучающего набора данных для глубокого обучения из коллекции изображений Sentinel-1. В данном исследовании авторы использовали изображения SAR из двух выдающихся прибрежных зон: провинции Куангнинь и Соктранга и Бакльеу, в качестве данных для обучения глубокой сети.

Шаг 2: Предварительная обработка спутниковых изображений SAR с использованием многоканальных синтезов для улучшения

наблюдаемости и выделения приливо-отливных отмелей.

Шаг 3: Подготовка входных данных для обучения сверточной нейронной сети U-Net с помощью методов обрезки изображений и разметки объектов, необходимых для процесса обучения.

Шаг 4: Обучение нейронной сети с использованием методов оптимизации, передачи обучения и настройки сети U-Net для до-

стижения максимальной точности в процессе обучения, которая оценивается с помощью размеченных данных обучения.

Шаг 5: Применение модели на всем прибрежном регионе Вьетнама для определения приливно-отливных отмелей и статистического анализа их площади в пределах региональных границ.

Шаг 6: Расширение применения метода для определения формы приливно-отливных отмелей в нескольких прибрежных районах Вьетнама.

### Данные обучения и тестирования

Авторы использовали изображения Sentinel-1 (SAR) из района Монгкай в провин-

ции Куангнинь для обучения сети U-Net, представляющие типичные приливно-отливные отмели северного Вьетнама. Для улучшения модели были добавлены образцы из южных прибрежных районов провинций Шокчанг и Бакльеу (рис. 2). Техники настройки нейронной сети и передачи обучения повысили классификационную способность модели. Изображения Sentinel-1, собранные в условиях низких приливов, позволили выделить максимально возможные по площади отмели. Идентификацию отмелей улучшили с использованием изображений Sentinel-2. Для обучения модели использовались изображения Sentinel-1 с масками, обучение проводилось на 80 % данных, а проверка – на 20 %.




Рис. 2. Данные обучения

Для улучшения распознавания отмелей на изображениях Sentinel-1 был добавлен канал «Ratio» (VH/VV) [18], созданный путем деления одного радиолокационного канала на дру-

гой. Более высокие значения канала «Ratio» указывают на наличие воды, низкие – на сушу. Данные Sentinel-1 вдоль побережья Вьетнама, собранные в 2022 г. в условиях низких прили-

вов, были предварительно обработаны на платформе Google Earth Engine и использованы как тестовый набор для модели U-Net [19]. С помощью U-Net проводилась сегментация и распознавание отмелей с высокой точностью.

Экспериментальные данные модели глубокого обучения, полученные для автоматического обнаружения прибрежных приливных отмелей во Вьетнаме (рис. 3), приведены в таблице




Рис. 3. Изображения Sentinel-1 вдоль береговой линии Вьетнама, которые использовались в качестве тестовых данных для моделирования определения прибрежных приливно-отливных отмелей

Данные изображений Sentinel-1 для тестирования модели классификации прибрежных приливно-отливных отмелей во Вьетнаме

№	Индексы изображения
1	S1A_IW_GRDH_1SDV_20221226T105830_20221226T105855_046502_05925E_7439
2	S1A_IW_GRDH_1SDV_20221226T105805_20221226T105830_046502_05925E_C667
3	S1A_IW_GRDH_1SDV_20220117T110600_20220117T110625_041500_04EF67_E054
4	S1A_IW_GRDH_1SDV_20220318T110534_20220318T110559_042375_050D68_AAA4
5	S1A_IW_GRDH_1SDV_20220330T110509_20220330T110534_042550_05135E_C7C2
6	S1A_IW_GRDH_1SDV_20220629T105648_20220629T105713_043877_053CEB_7C61
7	S1A_IW_GRDH_1SDV_20220418T105619_20220418T105644_042827_051C99_498E
8	S1A_IW_GRDH_1SDV_20220617T105558_20220617T105623_043702_0537A8_ADEB
9	S1A_IW_GRDH_1SDV_20221226T105531_20221226T105600_046502_05925E_C370
10	S1A_IW_GRDH_1SDV_20220809T110333_20220809T110402_044475_054EB1_5935
11	S1A_IW_GRDH_1SDV_20221130T111119_20221130T111148_046123_058580_D983
12	S1A_IW_GRDH_1SDV_20220907T111119_20220907T111148_044898_055CE8_F874
13	S1A_IW_GRDH_1SDV_20221224T111147_20221224T111212_046473_059172_96D9

### Подготовка данных и обучение сети U-Net

Спутниковые снимки Sentinel-1, предварительно обработанные с помощью Google Earth Engine, были загружены и размечены в ArcGIS Pro. Из-за различий в характеристиках приливных зон вдоль побережья Вьетнама для обучения модели U-Net использовались данные из двух регионов: район Монгкай в провинции Куангнинь (север Вьетнама) и прибрежные районы провинций Сокчанг и Бакльеу (юг Вьетнама).

На первом этапе модель U-Net была обучена на наборе данных из района Монгкай, сочетая спутниковые снимки с размеченными данными для распознавания приливных зон. После завершения начального обучения модель приобрела способность автоматически

классифицировать объекты. Для применения модели к южным регионам и повышения её точности распознавания авторы использовали технику трансферного обучения и тонкой настройки нейронной сети [20]. Нейронная сеть была дообучена с применением спутниковых данных из прибрежных районов провинций Сокчанг и Бакльеу, что позволило модели изучить новые особенности без необходимости повторного обучения с нуля. Это способствовало повышению точности автоматического распознавания объектов. Образцы изображений были разделены на три категории: суша, приливные зоны и вода. После завершения отбора образцов изображения были обработаны в ArcGIS Pro, где они были размечены и разделены на фрагменты размером  $256 \times 256 \times 3$  канала (R-VV; G-VH; B-VV/VH) (рис. 4).




Рис. 4. Подготовка обучающих данных  
а) изображения Sentinel-1; б) маска объектов

### Оценка точности

По завершении процесса обучения авторы разделили данные на 80 % для обучающего набора и 20 % для набора тестов, чтобы оценить точность модели после завершения обучения. Для проверки точности классификации использовались метрики [14], такие как точность (Precision) (1), полнота (Recall) (2), F1-мера (F1-score) (3) и Accuracy (4). Эти оценки направлены на измерение эффективности модели на тестовом наборе данных, что обеспечивает глубокое понимание ее способности обрабатывать новые данные

$$\text{Точность (Precision)} = \frac{TP}{TP+FP}; \quad (1)$$

$$\text{Полнота (Recall)} = \frac{TP}{TP+FN}; \quad (2)$$

$$F1\text{-мера} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}; \quad (3)$$

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN}; \quad (4)$$

где *TP-True Positive* – Истинно положительное; *TN-True Negative* – Истинно отрицательное; *FP-False Positive* – Ложно положительное; *FN-False Negative* – Ложно отрицательное.

### Результаты

#### Результаты на тренировочном наборе данных

Процесс обучения включал 50 эпох на первом этапе обучения и 20 эпох на этапе тонкой настройки нейронной сети. Для повышения точности распознавания и интеграции новых обучающих образцов был применен метод пере-

носа обучения. В результате модель была обучена на 80 % данных и протестирована на 20 % данных. Итоговая модель достигла общей точности 94,42 % на проверочном наборе данных. Процесс обучения и проверки модели был выполнен с использованием фреймворка Keras/TensorFlow и интегрирован с библиотеками ArcGIS Pro, проводился в среде Jupyter Notebook.




Рис. 5. Результаты, полученные на основе данных обучения модели U-Net для распознавания приливно-отливных отмелей:

- а) результаты, полученные на основе первоначальных данных обучения (Монгкай, Куангнинь);  
 б) результаты, полученные на основе данных, использованных для настройки нейронной сети (Шокчанг и Бакльеу)

### **Применение модели для определения приливно-отливных отмелей на побережье Вьетнама**

Модель успешно применялась для точного определения приливно-отливных отмелей на побережье Вьетнама с использованием данных спутниковых снимков Sentinel-1. Результаты исследования подтвердили высокую точность модели в этом задании благодаря способностям глубоких нейронных сетей к обобщению и адаптации (рис. 6).

Результаты показывают, что приливно-отливные отмели сосредоточены в основном в северной части прибрежной зоны Вьетнама, занимая площадь 60 806,4 га (32 %), главным образом в прибрежных районах провинций Куангнинь и Хайфонг. В прибрежной зоне дельты реки Меконг они занимают площадь 63 901,3 га (34 %), сосредоточены в трех прибрежных провинциях: Бенче, Шокчанг и Бакльеу. Дельта Красной реки также характеризуется большим и плотным распространением приливно-отливных отмелей, занимающих площадь 19 442,09 га (10 %), распре-

Результаты обучения сети U-Net для обнаружения приливно-отливных отмелей в двух регионах – Монгкай (Куангнинь, Вьетнам) и Шокчанг, Бакльеу – показали высокую точность и полноту. Эти результаты почти совпадают с исходными обучающими и уточняющими данными, что отражено на изображении (рис. 5).

ленных вдоль побережья и сосредоточенных у устьев таких рек, как Красная река, Ванук и Дай, благодаря отложению аллювиальных наносов из этих рек. В Северо-Центральной и Южно-Центральной частях Вьетнама площадь приливно-отливных отмелей меньше, соответственно 17 977,18 га (10 %) и 19 442,09 га (14 %). Эти отмели представляют собой накопительные формы рельефа, образованные приливами, расположенные выше среднего уровня моря, заболоченные или подверженные заболачиванию при подходящих условиях. Почва постоянно влажная из-за приливов, в условиях спокойного волнения, и мангровая растительность процветает благодаря высокому содержанию органического ила в отложениях. На основе автоматической классификации исследовательская группа подсчитала площадь приливно-отливных отмелей в 28 прибрежных провинциях Вьетнама (рис. 7). Среди них Куангнинь является провинцией с наибольшей площадью приливно-отливных отмелей в Вьетнаме – 51 953,91 га, за которой следуют провинции Шокчанг и Бакльеу.



стоянно смещающейся границы из-за приливов и отливов. Использование линии водораздела для определения береговой линии основано на изменении этих линий в зависимости от уровня моря при приливах.

В данном исследовании высота линии водораздела определялась методом извлечения данных о приливах с использованием официальных данных о высоте приливов для портов Франции и более чем 1 000 других точек по всему миру (<https://maree.shom.fr/>). Этот инструмент позволяет опре-

делить уровень приливов в конкретное время и в конкретном месте.

Авторы применили модель глубокого обучения для выявления приливно-отливных отметей, сочетая это с данными о высоте приливов. Метод был протестирован на отмели устья реки Ванук, Тхайбинь, Вьетнам. Высотная точка прилива находилась в Дошон, Хайфонг, Вьетнам (20° 40' 00.0" N, 106° 49' 00.0" E). Береговые линии в разные моменты времени были интерполированы для создания цифровой модели рельефа (ЦМР) отмели (рис. 8).




Рис. 8. Морфология приливной отмели в устье реки Ванук, Тхайбинь, которая была получена путем применения метода определения береговой линии на основе полученной модели глубокого обучения

Для оценки точности полученной ЦМР 02.09.2023 г. было проведено полевое исследование, которое показало среднюю абсолютную ошибку 11 см по сравнению с полученными результатами ЦМР. Эти результаты демонстрируют, что метод береговых линий воды, основанный на изображениях SAR и глобальной приливной модели, может быть использован для создания предварительных карт морфологии крупных приливно-отливных отмелей.

### Заключение

Приливно-отливные отмели играют важную роль в очистке окружающей среды и смягчении последствий ураганов и цунами, защи-

щая береговую линию. Однако их площадь уменьшается из-за систем защиты от наводнений, а оставшиеся зоны подвергаются загрязнению и изменению климата. Для их сохранения необходим тщательный мониторинг.

Статья описывает достижения в использовании методов дистанционного зондирования для идентификации и оценки приливно-отливных отмелей, что важно для защиты прибрежных районов Вьетнама. Использование нейронной сети U-Net в сочетании с данными спутников Sentinel-1 из провинций Куангинь и Соктранг позволяет быстро и точно распознавать отмели. Применение радиолокационных изображений преодолевает ограничения облачности и обеспечивает непре-

рывный мониторинг, открывая возможности для сбора данных и анализа.

Статья также рассматривает возможность расширения модели для оценки морфологии прибрежных наносов и её применения в устье реки Тхайбинь. Это показывает потенциал метода для изучения изменений прибрежной среды. Модель глубокого обучения используется для создания карты приливно-отливных отмелей вдоль побережья Вьетнама и предо-

ставления подробной статистики по 28 прибрежным провинциям. Это помогает руководителям более эффективно управлять и использовать эти ресурсы.

Кроме того, упоминается метод использования водных путей для определения формы отмелей вдоль побережья, что позволяет отслеживать изменения, оценивать объем илов и морфологию прибрежных отмелей более точно и эффективно, экономя время и ресурсы.

## БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Miththapala S. Mangrove Coastal Ecosystem Series // Ecosystem and Livelihoods Groups Asia IUCN. – 2008. – Vol. 2.
2. McLean R. F., Tsyban A., Burkett V. Coastal zones and marine ecosystems // Climate change. – 2001. – P. 343–379.
3. Klein G. D. Intertidal flats and intertidal sand bodies // Coastal sedimentary environments. New York. – 1985. – P. 187–224.
4. Tong S. S., Deroin J. P., Pham T. L. An optimal waterline approach for studying tidal flat morphological changes using remote sensing data: A case of the northern coast of Vietnam // Estuarine, Coastal and Shelf Science. – 2020. – Vol. 4. – DOI 10.1016/j.ecss.2020.106613.
5. Perillo G., Wolanski E., Cahoon D. R., Hopkinson C. S. Coastal wetlands: an integrated ecosystem approach // Elsevier. – 2018.
6. Morris J. T., Sundareshwar P. V., Nietch C. T., Kjerfve B., Cahoon D. R. Responses of coastal wetlands to rising sea level // Ecology. – 2002. – Vol. 83(10). – P. 2869–2877. – DOI 10.1890/0012-9658(2002)083[2869:ROCWTR]2.0.CO;2.
7. Murray N. J., Phinn S. R., Clemens R. S., Roelfsema, C. M., Fuller R. A. Continental scale mapping of tidal flats across East Asia using the Landsat archive. Remote Sensing. – 2012. – Vol. 4 (11). – P. 3417–3426. DOI 10.3390/rs4113417.
8. Zhao B., Guo H., Yan Y., Wang Q., Li B. A simple waterline approach for tidelands using multi-temporal satellite images: A case study in the Yangtze Delta // Estuarine, Coastal and Shelf Science. – 2008. – Vol. 77 (1). – P. 134–142. – DOI 10.1016/j.ecss.2007.09.022.
9. Khan AI., Al-Habsi S. Machine learning in computer vision // Procedia Computer Science. – 2020. – Vol. 167. – P. 444–4451. – DOI 10.1016/j.procs.2020.03.355.
10. Аш Е. В. Общие принципы и методика создания карты береговых морфосистем на основе анализа данных дистанционного зондирования Земли // Исследование Земли из космоса. – 2014. – № 6. – С. 40. – DOI 10.7868/S0205961414050029.
11. Куен Д. Т., Малинников В. А. Классификация устьевых и прибрежных водно-болотных угодий по снимкам Planet NICFI на основе сверточных нейронных сетей и трансферного обучения // Геодезия и картография. – 2024. – № 6. – С. 31–42. – DOI 10.22389/0016-7126-2024-1008-6-31-42.
12. Siddique N., Paheding S., Elkin CP., Devabhaktuni V. U-net and its variants for medical image segmentation: A review of theory and applications // Ieee Access. – 2021. – Vol. 9. – P. 82031–82057. – DOI 10.1109/ACCESS.2021.3086020.
13. Pan Z., Xu J., Guo Y., Hu Y., Wang G. Deep learning segmentation and classification for urban village using a worldview satellite image based on U-Net // Remote Sensing. – 2020. – Vol. 12 (10). – P. 1574. – DOI 10.3390/rs12101574.
14. Fan X., Yan C., Fan J., Wang N. Improved U-net remote sensing classification algorithm fusing attention and multiscale features // Remote Sensing. – 2022. – Vol. 14(15). – P. 3591. – DOI 10.3390/rs1415359.

15. Xu Y., Zhang H., Li Y. A Comparative Analysis of Water Indices for Delineating Water Bodies from Landsat TM Imagery // *Remote Sensing*. – 2017. – Vol. 9(2). – P. 141. – DOI 10.3390/rs902014.
16. Байкин Д. А. Анализ влияния разлива нефтепродуктов на состояние природных объектов по данным дистанционного зондирования Sentinel-2 в условиях Восточной Сибири // *Интерэкспо ГЕО-Сибирь. XVII Междунар. науч. конгр., 19–21 мая 2021 г., Новосибирск : сб. материалов в 8 т. Т. 6 : Магистерская научная сессия «Первые шаги в науке»*. – Новосибирск : СГУГиТ, 2021. – С. 24–31. – DOI 10.33764/2618-981X-2021-6-24-31.
17. Zhang S., Xu Q., Wang H., Kang Y., Li X. Automatic waterline extraction and topographic mapping of tidal flats from SAR images based on deep learning // *Geophysical Research Letters*. – 2022. – Vol. 49(2). – DOI 10.1029/2021GL096007
18. Yadav R., Nascetti A., Ban Y. Deep attentive fusion network for flood detection on uni-temporal Sentinel-1 data // *Frontiers in Remote Sensing*. – 2022. – Vol. 3. – DOI 10.3389/frsen.2022.1060144.
19. Ronneberger O., Fischer P., Brox T. U-net: Convolutional networks for biomedical image segmentation // *Medical image computing and computer-assisted intervention—MICCAI 2015*. – 2015. – P. 234–241.
20. Andrew O., Apan A., Paudyal DR. Convolutional Neural Network-Based Deep Learning Approach for Automatic Flood Mapping Using NovaSAR-1 and Sentinel-1 Data // *ISPRS International Journal of Geo-Information*. – 2023. – Vol 12 (5). – DOI 10.3390/ijgi12050194.
21. Murray, N. J., Phinn, S. R., Clemens, R. S, Roelfsema, C. M., Fuller, R. A. Continental scale mapping of tidal flats across East Asia using the Landsat archive. *Remote Sensing*. – 2012. – Vol. 4 (11). – P. 3417–3426. – DOI 10.3390/rs4113417.
22. Kim K., Jung H. C., Choi J. K., Ryu J. H. Statistical analysis for tidal flat classification and topography using multitemporal SAR backscattering coefficients. *Remote Sensing*. – 2021. – Vol. 13 (24). – P. 5169. – DOI 10.3390/rs13245169.
23. Колесников А. А. Анализ методов и средств искусственного интеллекта для анализа и интерпретации данных активного дистанционного зондирования // *Вестник СГУГиТ*. – 2022. – Т. 27, № 3. – С. 74–94. – DOI 10.33764/2411-1759-2022-27-3-74-94.

### Об авторах

*Динь Туен Куен* – аспирант кафедры космического мониторинга и экологии.

*Василий Александрович Малинников* – доктор географических наук, заведующий кафедрой космического мониторинга и экологии.

*Темесген Эйясу Серек* – аспирант кафедры географии картографического факультета.

*Суан Хиен Нго* – аспирант кафедры экономики и управления недвижимостью.

Получено 02.07.2024

© Д. Т. Куен, В. А. Малинников, Т. Э. Серек, С. Х. Нго, 2024

### Mapping tidal flats along the coast of Vietnam using deep learning techniques based on Sentinel-1 imagery

*D. T. Quyen<sup>1</sup>*, *V. A. Malinnikov<sup>1</sup>*, *T. E. Sereke<sup>1</sup>*, *X. H. Ngo<sup>2</sup>*

<sup>1</sup> Moscow State University of Geodesy and Cartography, Moscow, Russian Federation

<sup>2</sup> State University of Land Use Planning, Moscow, Russian Federation

e-mail: quyendinhuyen97@gmail.com

**Abstract.** The article presents the results of a study using remote sensing methods and deep learning with the U-Net network, combined with transfer learning and network fine-tuning techniques, to study and manage tidal flats — an important part of the wetlands in the coastal zones of Vietnam. The use

of images from the Sentinel-1 satellite allows for continuous observation under all weather conditions due to its ability to penetrate clouds and operate independently of weather. The authors developed a U-Net deep learning model, applying transfer learning and network fine-tuning to optimize the data training process. As a result, a model capable of automatically classifying tidal flats with high accuracy, reaching 94.42%, was created. Data collected from various geographic locations in both northern and southern regions of Vietnam were used to train the model. The model was then applied to determine the area of tidal flats along the entire coastline of 28 provinces of Vietnam. Additionally, the model was extended to identify the morphology of the tidal flats, providing useful information for managing coastal wetlands and protecting the shoreline.

**Keywords:** tidal flats, remote sensing, deep learning, U-Net network, Sentinel-1, Vietnam, wetlands, tidal flats morphology, geoinformation mapping, wetland maps

## REFERENCE

1. Miththapala, S. (2008). Mangrove Coastal Ecosystem Series. *Ecosystem and Livelihoods Groups Aisia IUCN*, 2.
2. McLean, R. F., Tsyban, A., Burkett, V., & et al. (2001). Coastal zones and marine ecosystems. *Climate change*, 343–379.
3. Klein, G. D. (1985). Intertidal flats and intertidal sand bodies. *Coastal sedimentary environments*. New York, 187–224.
4. Tong, S. S., Deroin, J. P., & Pham, T. L. (2020). An optimal waterline approach for studying tidal flat morphological changes using remote sensing data: A case of the northern coast of Vietnam. *Estuarine, Coastal and Shelf Science*. 4. DOI 10.1016/j.ecss.2020.106613.
5. Morris, J. T., Sundareshwar, P. V., Nietch, C. T., Kjerfve, B., & Cahoon, D. R. (2002). Responses of coastal wetlands to rising sea level. *Ecology*, 83(10), 2869–2877. DOI 10.1890/0012-9658(2002)083[2869:ROCWTR]2.0.CO;2.
6. Perillo G., Wolanski E., Cahoon D. R., Hopkinson C. S. (2018). Coastal wetlands: an integrated ecosystem approach. *Elsevier*.
7. Murray N. J., Phinn S. R., Clemens R. S., Roelfsema, C. M., & Fuller, R. A. (2012). Continental scale mapping of tidal flats across East Asia using the Landsat archive. *Remote Sensing*, 4 (11), 3417–3426. DOI 10.3390/rs4113417.
8. Zhao B., Guo H., Yan, Y., Wang Q., & Li B. (2008). A simple waterline approach for tidelands using multi-temporal satellite images: A case study in the Yangtze Delta. *Estuarine, Coastal and Shelf Science*, 77(1), 134–42. DOI 10.3390/rs4113417.
9. Khan, AI., & Al-Habsi S. (2020). Machine learning in computer vision. *Procedia Computer Science*, 167, 1444–1451, DOI 10.3390/rs4113417.
10. Ash E. V. General Principles and Methods of Coastal Morphosystems Mapping Based on the Remote Sensing Data Analysis. (2014). *Issledovanie Zemli iz kosmosa [Exploring the Earth from Space]*, 6, 40, DOI 10.7868/S0205961414050029. [in Russian].
11. Quyen D. T., & Malinnikov V. A. (2024) Classification of estuaries and coastal wetlands from Planet-NICFI imagery based on convolutional neural networks and transfer training. *Geodezia i Kartografiya [Geodesy and cartography]*, 85 (6), 31–42. DOI 10.22389/0016-7126-2024-1008-6-31-42 [In Russian].
12. Siddique N., Paheding S., Elkin CP., & Devabhaktuni V. (2021). U-net and its variants for medical image segmentation: A review of theory and applications. *Ieee Access*, 9, 82031–82057.
13. Pan Z., Xu J., Guo Y, Hu Y., & Wang G. (2020) Deep learning segmentation and classification for urban village using a worldview satellite image based on U-Net. *Remote Sensing*, 12(10), 1574, DOI 10.3390/rs12101574.
14. Fan, X., Yan, C., Fan, J., & Wang N. (2022). Improved U-net remote sensing classification algorithm fusing attention and multiscale features. *Remote Sensing*, 14(15), 3591, DOI 10.3390/rs1415359.

15. Xu, Y., Zhang, H., & Li, Y. (2017). A Comparative Analysis of Water Indices for Delineating Water Bodies from Landsat TM Imagery. *Remote Sensing*, 9(2), 141. DOI 10.3390/rs9020141.
16. Baikin, D. A. (2021). Analysis of the impact of oil product spills on natural objects based on Sentinel-2 remote sensing data in *Eastern Siberia. Interekspo Geo-Sibir'. Vol. 6 [Interexpo Geo-Siberia. Vol. 6]* 24–31, DOI 10.33764/2618-981X-2021-6-24-31. [in Russian].
17. Zhang, S., Xu Q., Wang, H., Kang, Y., & Li X. (2022). Automatic waterline extraction and topographic mapping of tidal flats from SAR images based on deep learning. *Geophysical Research Letters*, 49(2), DOI 10.1029/2021GL096007.
18. Yadav, R., Nascetti A., & Ban Y. (2022). Deep attentive fusion network for flood detection on uni-temporal Sentinel-1 data. *Frontiers in Remote Sensing*, 3, DOI 10.3389/frsen.2022.1060144.
19. Ronneberger, O., Fischer, P., & Brox T. (2015). U-net: Convolutional networks for biomedical image segmentation. *Medical image computing and computer-assisted intervention–MICCAI 2015*, 234-241.
20. Andrew, O., Apa, A., & Paudyal, DR. (2023). Convolutional Neural Network-Based Deep Learning Approach for Automatic Flood Mapping Using NovaSAR-1 and Sentinel-1 Data. *ISPRS International Journal of Geo-Information*, 12(5), DOI 10.3390/ijgi12050194.
21. Murray, N. J., Phinn, S. R., Clemens, R. S, Roelfsema, C. M., & Fuller, R. A. (2012). Continental scale mapping of tidal flats across East Asia using the Landsat archive. *Remote Sensing*, 4(11), 3417–3426, DOI 10.3390/rs4113417.
22. Kim, K., Jung, H. C., Choi, J. K., & Ryu, J. H. (2021). Statistical analysis for tidal flat classification and topography using multitemporal SAR backscattering coefficients. *Remote Sensing*. 13(24), 5169, DOI 10.3390/rs13245169.
23. Kolesnikov, A. A. (2022). Analysis of methods and tools of artificial intelligence for analysis and interpretation of active remote sensing data. *Vestnik SGUGiT [Vestnik SSUGT]*, 27(3), 74–94. DOI 10.33764/2411-1759-2022-27-3-74-94. [in Russian].

### Author details

*Dinh Tuyen Quyen* – PhD Student, Department of Geography with Specialization in Aerospace Based Remote Sensing of the Earth, Photogrammetry.

*Vasily A. Malinnikov* – D. Sc., Head of Department of Space Monitoring and Ecology.

*Temesgen Eyassu Sereke* – Ph. D. Student, Department of Geography of the Cartographic Faculty.

*Xuan Hien Ngo*– Ph. D. Student, Department of Economics and Real Estate Management.

Received 02.07.2024

© D. T. Quyen, V. A. Malinnikov, T. E. Sereke, X. H. Ngo, 2024